

مدل‌سازی دمای روزانه خاک با استفاده از داده‌های سینوپتیکی و شبکه عصبی

- ❖ **طیبه مصباح زاده***: استادیار دانشکده منابع طبیعی، دانشگاه تهران
- ❖ **فرشاد سلیمانی ساردو**: دانشجوی دکتری دانشکده منابع طبیعی، دانشگاه تهران
- ❖ **الهام رفیعی ساردویی**: استادیار دانشکده منابع طبیعی، دانشگاه جیرفت
- ❖ **فاطمه فرزانه پی**: دانش آموخته کارشناسی ارشد، دانشکده منابع طبیعی، دانشگاه تهران

چکیده

دمای خاک یکی از مهم‌ترین پارامترهای تأثیرگذار بر روی فرایندهای هیدرولوژیکی می‌باشد و یکی از عوامل مؤثر در استقرار پوشش گیاهی در مناطق خشک است. بررسی‌ها نشان داده است دمای خاک تحت تأثیر پارامترهایی از قبیل متوسط دمای هوای روزانه، حداقل و حداکثر دمای روزانه، تبخیر، تابش خورشیدی، تعداد ساعات آفتابی و بارش می‌باشد؛ شناخت از مدل تغییرات دما در اعماق مختلف خاک می‌تواند در تعیین نیاز آبی گیاهان و فعالیت‌های بیولوژیکی بسیار مؤثر باشد. با توجه به اهمیت موضوع، در این مطالعه از داده‌های سینوپتیکی اصفهان به منظور مدل‌سازی دمای خاک در عمق ۵ تا ۱۰۰ سانتی متری خاک با استفاده از شبکه عصبی-مصنوعی استفاده شد. نتایج نشان داد که خطای مدل با افزایش عمق افزایش پیدا می‌کند به طوری که بیشترین خطای مدل در عمق ۱۰۰ سانتی متری و کمترین خطای مدل‌ها در عمق ۱۰ سانتی متر از سطح می‌باشد. همچنین نتایج نشان داد افزایش خطای مدل-های شبکه عصبی مصنوعی در شبیه‌سازی تغییرات دمای خاک در لایه‌های عمقی می‌باشد و علت اصلی افزایش کارایی مدل‌های هوش مصنوعی در شبیه‌سازی دمای خاک در لایه‌های سطحی نسبت به لایه‌های تحتانی عمدتاً مربوط به کاهش همبستگی بین پارامترهای اقلیمی و تغییرات دمای خاک در لایه‌های تحتانی نسبت به لایه‌های فوقانی است. به طوری که ضریب تغییرپذیری دمای خاک با افزایش عمق نسبت به لایه‌های سطحی کمتر است و کمتر تحت تأثیر متغیرهای اقلیمی از جمله دمای خاک قرار می‌گیرد.

کلید واژگان: دمای خاک، شبکه عصبی، ایستگاه سینوپتیک اصفهان

۱. مقدمه

شبکه‌های عصبی مصنوعی در برآورد دمای خاک می‌باشد. کانگ و همکاران [۱۳] مدل هیبرید دمای خاک را با در نظر گرفتن تأثیر ترکیبی توپوگرافی، پوشش گیاهی و لاشبرگ جهت پیش‌بینی دمای خاک در مناطق جنگلی در کره به کار گرفتند. تحلیل حساسیت مدل نشان داد مدل حساسیت بالایی به شاخص سطح برگ (LAI) نشان می‌دهد. کواهو و همکاران [۷] از تلفیق شبکه‌های عصبی شعاعی و روش خوشه‌بندی جهت شبیه‌سازی دمایی پروفیل خاک بهره گرفتند. نتایج آنها نشان داد تلفیق این دو روش قابلیت بالایی در تعیین رفتار حرارتی و رطوبتی خاک در اعماق مختلف دارد. مدل‌هایی که بر اساس گام‌های ماهانه یا سالانه هستند ممکن است نتوانند به‌درستی تغییرات دینامیک دمای خاک را پیش‌بینی کنند بنابراین اندازه‌گیری دمای روزانه خاک در هر منطقه بسیار مهم است. از طرفی اندازه‌گیری دمای خاک برای مقاطع طولانی و بلندمدت مشکل و هزینه‌بر است [۱۶]. لذا هدف اصلی این مطالعه بررسی، مطالعه و برآورد دمای خاک با استفاده از مدل‌های سری زمانی و نیز روش رگرسیون چندمتغیره می‌باشد. با این وجود یکی از متغیرهای اصلی که نقش مهمی در مطالعات هیدرولوژیک و برآورد تبخیر و تعرق و میزان جریان رودخانه دارد دمای خاک است که کمتر مورد مطالعه و مدل‌سازی قرار گرفته است. سبزی پرور و همکاران [۲۰] با استفاده از شبکه‌های استنتاج تطبیقی عصبی - فازی با مدل‌های رگرسیونی به‌منظور برآورد دمای اعماق خاک در سه اقلیم متفاوت پرداختند. در این مطالعه از داده‌های سینوپتیکی سه ایستگاه تهران، زاهدان و رامسر که معرف سه اقلیم متفاوت هستند استفاده شد همچنین دوره آماری ۱۵ ساله (۲۰۰۶-۱۹۹۲) برای مطالعه دمای خاک انتخاب گردید و نتایج نشان داد برخلاف مناطق خشک در ایستگاه رامسر که معرف اقلیم مرطوب بود با افزایش عمق خاک دقت پیش‌بینی تا ۱۸ درصد افزایش می‌یابد در حالیکه در دو ایستگاه دقت پیش‌بینی دمای خاک در لایه‌های کم‌عمق تا ۱۰ درصد بیشتر از لایه‌های عمیق می‌باشد. قائمی نیا و همکاران

دمای خاک یکی از پارامترهای مهم و تأثیرگذار در مطالعات کشاورزی و هیدرولوژی است نظر به اینکه رطوبت قابل دسترس گیاهان به دمای خاک بستگی دارد مطالعه و تحقیق در این‌باره امری ضروری و اجتناب ناپذیر به نظر می‌رسد. با توجه به مطالعات صورت گرفته که نقش دمای خاک را در مطالعات کشاورزی، کاربردهای مهندسی [۱] مدل‌سازی‌های هیدرولوژیک و... نشان می‌دهند، لذا لزوم تأکید بر اهمیت درک تغییرات دمای خاک احساس می‌شود. بر اساس مطالعات قبلی تغییرات دمایی و رطوبتی خاک در عمق‌های کم نوسانات معنی‌داری را هم در مقیاس روزانه و هم در مقیاس سالانه نشان می‌دهد. بنابراین پیش‌بینی دمای خاک مشکل است. با در نظر گرفتن تغییرات دمایی خاک بررسی روش‌های عددی که توانایی پیش‌بینی صحیح رفتار حرارتی خاک را دارند برای ارزیابی تغییرات دمای خاک در طول زمان در جهت اهداف فعالیت‌های کشاورزی می‌تواند مفید باشد. بهایگل و همکاران [۳] نشان دادند که دمای خاک یکی از متغیرهای مهم در مطالعات منابع آبی (هیدرولوژی)، اقلیم‌شناسی و همچنین کشاورزی محسوب می‌شود و همچنین کمپ و همکاران [۱۵] و ین و همکاران [۲۲] اعلام کردند که این پارامتر می‌تواند نقش بسیار برجسته‌ای در تمام اکوسیستم‌ها از اکوسیستم‌های مناطق خشک بیابانی تا مناطق مرطوب (جنگلی) را ایفاد کند. تاکنون روش‌های مختلفی از جمله شبکه‌های عصبی مصنوعی [۱۰، ۱۷، ۱۸، ۲۱]، روش‌های آماری و تحلیل توافقی [۴، ۵، ۹، ۸، ۱۲] برای مدل‌سازی دمای خاک به کار گرفته شده است. یانگ و همکاران [۲۱] از شبکه‌های عصبی مصنوعی جهت شبیه‌سازی دمای خاک در عمق‌های مختلف ۱۰۰، ۵۰۰ و ۱۵۰۰ میلی‌متر، در یک مزرعه آزمایشی در اتاواای کانادا مورد استفاده قرار دادند. نتایج آنها با استفاده از دو معیار جذر میانگین مربعات خطا (RMSE) (۰/۵۹ تا ۰/۸۲) و ضریب همبستگی (۰/۹۳ تا ۰/۹۸) نشان‌دهنده کارایی بالای

خطی به ازای هر عمق خاک ارائه گردید. در این مطالعه سعی شده است تا با به کارگیری شبکه عصبی مصنوعی و داده‌های سینوپتیکی ایستگاه اصفهان دمای خاک در عمق ۵ تا ۱۰۰ سانتی‌متری شبیه‌سازی گردد و کارایی آنها در مدل‌سازی دمای خاک مورد ارزیابی قرار گیرد.

۲. روش شناسی

۲.۱. معرفی منطقه مورد مطالعه

برای انجام این مطالعه پارامترهای اقلیمی مربوط به ایستگاه سینوپتیک هواشناسی اصفهان از جمله متوسط دمای هوای روزانه، حداقل و حداکثر دمای روزانه، تبخیر، تابش خورشیدی، تعداد ساعات آفتابی و دمای خاک مربوط به عمق‌های ۵، ۱۰، ۲۰، ۳۰، ۵۰ و ۱۰۰ سانتی‌متر در طول دوره آماری ۱۳ ساله (۱۳۷۱-۱۳۸۴) برای منطقه اصفهان که از جمله مناطق خشک و نیمه‌خشک کشور و با تغییرات نسبتاً شدید آب و هوایی فصلی می‌باشد جمع‌آوری گردید. موقعیت منطقه مورد مطالعه در شکل ۱ نشان داده شده است.

۲.۲. شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی متفاوت از سیستم‌های معمولی از جمله مدل‌های آماری و یا تحلیلی می‌باشند. یک شبکه عصبی مصنوعی متشکل از تعداد دلخواه از عناصر بسیار ساده می‌باشد که گره نامیده می‌شود. هر گره یک عنصر بسیار ساده پردازشگر است که به ورودی‌های با وزن‌های مختلف که از گره‌های دیگر دریافت می‌کند، پاسخ می‌دهد. شبکه‌های عصبی شامل سه قسمت وزن است. این سه مؤلفه برای هر f و تابع انتقال b بایاس شبکه عصبی منحصر به فرد و مخصوص همان شبکه به ترتیب ورودی و a و p است. در رابطه‌های ارائه شده که به نام ورودی n خروجی شبکه عصبی است. پارامتر شبکه ۴ شناخته می‌شود که به عنوان ورودی تابع انتقال است و با توجه و پارامترهای عصبی ساخته می‌شود. رابطه میان p با توجه به پارامترهای معرفی شده در شکل

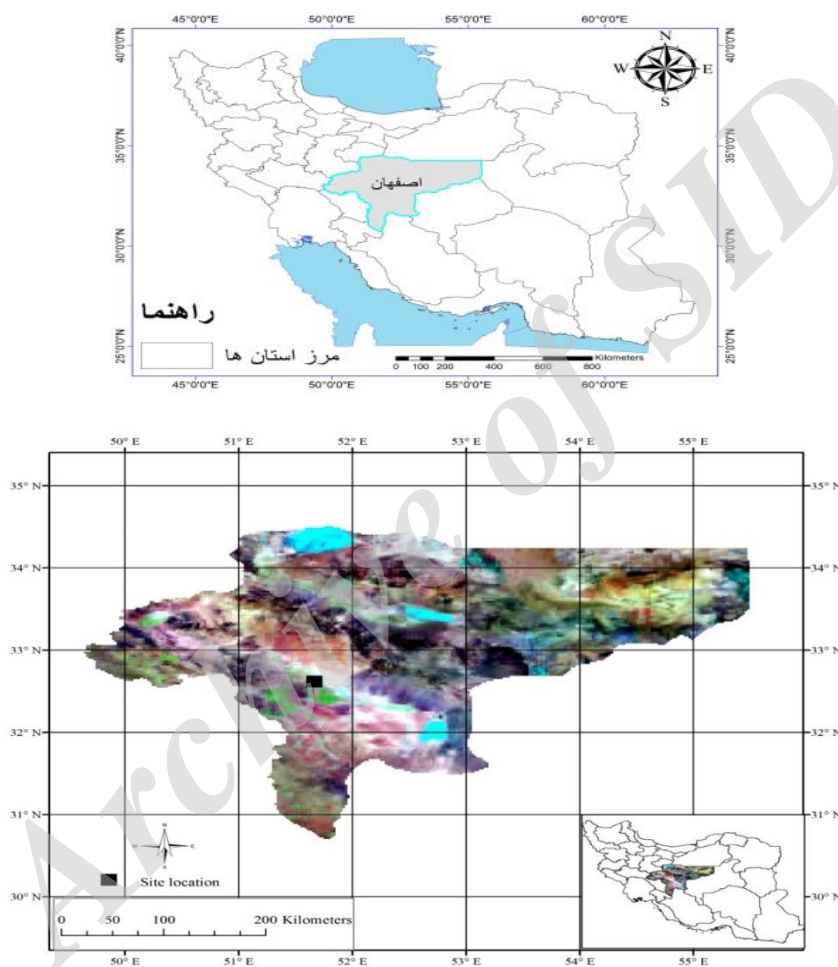
[۱۱] با استفاده از داده‌های سینوپتیک یزد به شبیه‌سازی تغییرات دمای اعماق خاک و بررسی عوامل جوی تأثیرگذار پرداختند؛ در این مطالعه هدف از انجام این تحقیق بررسی نقش عوامل جوی در تعیین دمای خاک می‌باشد. بدین منظور با جمع‌آوری داده‌های روزانه دمای خاک در اعماق ۵، ۱۰، ۲۰، ۳۰، ۵۰ و ۱۰۰ سانتی‌متری موجود در ایستگاه سینوپتیک یزد در سال ۱۳۸۵ اقدام به بررسی عامل‌های هواشناسی تأثیرگذار و تجزیه و تحلیل آنها شد و با استفاده از الگوی تغییرات سینوسی، دمای خاک این ایستگاه در طی سال شبیه‌سازی گردید. نتیجه اولیه نشان داد که بین عامل‌های جوی بارش، درجه حرارت هوا و ساعت آفتابی رابطه معنی‌دار وجود دارد. به طوری که مقایسه مقادیر اندازه‌گیری و پیشگویی مدل روی دستگاه مختصات نشان داد که مدل سینوسی با افزایش عمق، مقادیر را کمتر از مقدار واقعی برآورد می‌نماید. امیرمرادی و بهمنی [۱] با استفاده از شبکه عصبی مصنوعی به تعیین دمای روزانه خاک در سه عمق ۵، ۱۰ و ۳۰ سانتی‌متری پرداخته است نتایج به دست آمده حاکی از نقش مؤثر پیش پردازش روی متغیرها با استفاده از PCA بود دستاوردها نشان داد که شاخص‌های آماری r ، RMSE و MBE (در دوره صحت سنجی) به ترتیب برابر با ۰/۹۸، ۱/۶۱ و ۰/۲ برای مدل PCA-ANN بر روی پارامترهای دمای خاک در عمق ۵ سانتی‌متری نتیجه بهتری را به دنبال داشت. پارسافر و معرفی [۱۹] با استفاده روابط رگرسیونی، شبکه عصبی و شبکه عصبی-فازی به برآورد دمای عمق‌های مختلف خاک از دمای هوا با استفاده از داده‌های سینوپتیکی ایستگاه کرمانشاه پرداخته‌اند. نتایج نشان داد که در مورد روابط رگرسیونی، بر اساس ضریب همبستگی و پارامترهای خطا روابط خطی درجه سوم، خطی درجه دوم، خطی درجه اول، نمایی و لگاریتمی به ترتیب دارای بهترین برآورد بودند. همچنین نتایج نشان داد که بهترین و بدترین برآورد بین دمای هوا و دمای خاک به ترتیب در عمق ۵ سانتی‌متری و عمق ۱۰۰ سانتی‌متری خاک مشاهده گردید. نتایج حاصل از این مطالعه منجر به ارایه یک معادله درجه دوم و یک معادله

در فرایند آموزش عصبی، w و b (پارامترهای عصبی) تا زمانی که بهترین تقریب برای خروجی، با توجه به پارامترهای ورودی، به دست آورند ادامه دارند. طی فرآیند آموزش وزن‌ها (w) و مقادیر ثابتی که با آن‌ها جمع می‌شود، اصطلاحاً بایاس نامیده می‌شوند که به طور پی در پی تغییر می‌کند تا خطا به کمترین مقدار خود برسد [۱].


۲ به صورت شماتیکی نمایش داده شده است. شبکه عصبی مصنوعی از معادلات زیر پیروی می‌کند:

$$n = wp + b \quad \text{رابطه (۱)}$$

$$a = f(n) = f(wp + b) \quad \text{رابطه (۲)}$$



شکل ۱. موقعیت جغرافیایی منطقه مورد مطالعه



شکل ۲. شماتیکی از عملکرد شبکه عصبی مصنوعی [۱]

این تحقیق، شامل یک لایه ورودی، یک لایه پنهانی و یک لایه خروجی است. در این تحقیق از روش آموزش پس‌انتشار برای آموزش شبکه استفاده شد و از میان الگوریتم‌های مختلف این روش آموزش، الگوریتم لونی‌گر مارکوارت انتخاب گردید. تحقیقات نشان داده که برای اکثر کاربردها، این الگوریتم نتایج دقیق و سریعی نسبت به سایر روش‌های آموزش ارائه می‌دهد [۱].

داده‌های مورد استفاده به دو بخش تقسیم شد. بخش اول شامل ۳۰۲۸ مشاهده‌ای جهت آموزش مدل‌ها و ۳۳۵ داده مشاهده‌ای جهت صحت‌سنجی مدل‌ها مورد استفاده قرار گرفت. دو معیار ارزیابی معیار همبستگی (R2) و میانگین مجذور مربعات خطا (RMSE) جهت ارزیابی مدل‌ها مورد استفاده قرار گرفت. با توجه به اینکه پارامترهای ورودی مقیاس متفاوتی دارند لذا قبل از ورود به مدل در یک بازه عددی خاصی استاندارد گردیدند. با استفاده از فرمول زیر تمام ورودی‌ها بین -۱ و +۱ مقیاس گردیدند. این مقیاس‌سازی ورودی‌ها جهت افزایش کارایی تابع تانژانت سیگموئید در شبکه عصبی مصنوعی نیز مؤثر می‌باشد. از تابع زیر جهت مقیاس کردن ورودی‌ها و خروجی‌ها قبل از ورود به مدل‌های هوش مصنوعی استفاده گردید.

$$Z = \frac{2 * (X_i - X_{\min})}{(X_{\max} - X_{\min})} - 1 \quad (3)$$

در معادله بالا Z مقادیر استاندارد شده بین -۱ و +۱ و Xmax و Xmin به ترتیب کمترین و بیشترین مقدار ورودی و خروجی می‌باشد. همچنین برای ارزیابی مدل‌ها از R² و RMSE که از روابط زیر محاسبه می‌شوند استفاده گردید.

$$R^2 = \frac{\left(\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y}) \right)^2}{\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2} \quad (4) \text{ فرمول}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_i - Y_i)^2}{n}} \quad (5) \text{ فرمول}$$

تا کنون شبکه‌های عصبی مختلف با الگوریتم‌های مختلف در مطالعات هیدرولوژی مورد استفاده قرار گرفته است. در این مطالعه شبکه‌های پرسپترون چندلایه پیش‌خور با روش آموزش پس‌انتشار خطا ۱ مورد استفاده قرار گرفته است. انتخاب این نوع از شبکه‌های عصبی مصنوعی به این دلیل بوده است که در تحقیقات قبل، عملکرد بهتر این نوع شبکه‌ها نسبت به انواع دیگر شبکه‌های عصبی در زمینه هیدرولوژی و منابع آب به اثبات رسیده است [۶].

۱،۲،۲. سیستم استنتاج تطبیقی عصبی فازی (ANFIS)

روش آموزش اصلی در این سیستم، روش پس‌انتشار خطا است که در ترکیب با کمترین مجموع مربعات خطا، روش ترکیبی به دست می‌آید. در مجموع ANFIS از ساختاری ۵ لایه با تعدادی متغیر ورودی استفاده شد که هر ورودی دو یا چند تابع عضویت دارد. ساختار این سیستم با داده‌های ورودی، نوع تابع عضویت ورودی و خروجی، قوانین و تعداد تابع عضویت انتخاب می‌گردد. در مدل ANFIS توابع عضویت ورودی، شامل پی، مثلثی، دوزنقه‌ای، زنگوله‌ای، گوسی، گوسی ترکیبی، دو سیگموئیدی و حاصل ضرب دو سیگموئید و توابع عضویت خروجی که شامل ثابت و خطی می‌باشند. برای تخمین دمای خاک در عمق‌های خاک توسط ANFIS با تغییر الگوریتم آموزشی، توابع عضویت ورودی و خروجی و تعداد توابع عضویت در نظر گرفته برای داده‌های ورودی، در آرایش‌های مختلف اجرا گردید تا بهترین آرایش معرفی گردد. داده‌ها در شبکه عصبی مصنوعی و سیستم استنتاج عصبی-فازی به صورت دو مجموعه، داده‌های آموزش و داده‌های آزمایش آماده شدند [۲].

۲،۲،۲. مدل شبکه عصبی (ANN)

با ساختار پیش‌خور چندلایه برای تعیین دمای خاک در عمق‌های مختلف استفاده شد. ساختار مورد استفاده در

¹ Back Propagation

۳. نتایج

مخفی بر اساس آزمون و خطا بین ۱ تا $2m+1$ تعیین می‌گردد که m تعداد ورودی‌های مدل می‌باشد. جهت تعیین شبکه عصبی مصنوعی از الگوریتم لئونبرگ-مارگورات و ۳۰۰ دور آموزش استفاده گردید. مناسب‌ترین تعداد نورون در لایه مخفی برای شبیه‌سازی دمای خاک در لایه‌های ۵، ۱۰، ۲۰، ۳۰، ۵۰ و ۱۰۰ سانتی‌متر به ترتیب ۳، ۴، ۵، ۴، ۵ و ۳ نورون تعیین گردید. برای مثال جدول ۲ نشان‌دهنده آزمون و خطای مدل شبکه عصبی مصنوعی برای عمق‌های ۱۰ و ۵۰ سانتی‌متر است.

نتایج مدل شبکه عصبی مصنوعی بر اساس آماره‌های صحت‌سنجی ضریب تبیین (R^2) و مجذور میانگین مربعات خطا (RMSE) در جدول ۳ آورده شده است. نتایج مندرج در جدول نشان‌دهنده همبستگی بالای داده‌های مشاهده‌ای و شبیه‌سازی شده در اعماق مختلف خاک می‌باشد. به طوری که همبستگی بین داده‌های مشاهده‌ای و شبیه‌سازی شده از ۰/۹۸ در عمق ۵ سانتی‌متری تا ۰/۸۰ در عمق ۱۰۰ سانتی‌متری متغیر می‌باشد. نتایج نشان‌دهنده کارایی بالای مدل‌های هوش مصنوعی در شبیه‌سازی دمای پروفیل خاک می‌باشد.

جدول شماره ۱ مشخصات آماری سری پارامترهای مورد استفاده در تحقیق را نشان می‌دهد. با بررسی جدول مشخص می‌شود ضریب تغییرات (CV) دمای خاک از سطح به عمق ۱۰۰ سانتی‌متر افزایش قابل ملاحظه‌ای داشته است. به طوری که بیشترین ضریب تغییرات دمای خاک در عمق ۵ سانتی‌متری مشاهده می‌شود و به تدریج به سمت عمق کاهش پیدا می‌کند. مقادیر بالای ضریب تغییرات خاک در لایه‌های سطحی نشان‌دهنده بالا بودن میزان تغییر پذیری دمای خاک در این لایه می‌باشد که به نوبه خود متأثر از تنوع مکانیزم‌های مؤثر بر دمای خاک در این لایه‌ها می‌باشد. جهت شبیه‌سازی دمای خاک در اعماق ۵ تا ۱۰۰ سانتی‌متر از شش مدل شبکه عصبی مصنوعی استفاده گردید. جهت دستیابی به ساختار مناسب شبکه عصبی مصنوعی از فرایند آزمون و خطا جهت دستیابی به مناسب‌ترین ساختار شبکه عصبی بر اساس تعیین تعداد نورون‌های لایه مخفی استفاده گردید. بر اساس تعداد ورودی‌های مدل تعداد نورون‌های لایه مخفی تعیین می‌گردد. معمولاً تعداد نورون‌های لایه

جدول ۱. آماره‌های توصیفی سری‌های دمای خاک

آماره‌های توصیفی							متغیر	
CV (%)	کشیدگی	چولگی	انحراف معیار	میانگین	حداکثر	حداقل		
۵۴/۷۷	-۰/۷۳	-۰/۳۹	۷/۱۴	۱۳/۰۴	۲۸/۸۰	-۷/۸۰	(Co) حداقل دمای هوا	متغیرهای ورودی
۲۸/۷۶	-۰/۵۱	-۱/۶۰	۸/۲۰	۲۸/۵۳	۴۳	۱/۲۰	(Co) حداکثر دمای هوا	
۶۰/۸۱	۸/۴۹	۱/۳۸	۱۱۲۲/۴۲	۱۸۴۵/۶۷	۹۶۹۵	۲۵	(CAL/CM2) تابش	
۲۷/۵۶	۲/۷۴	-۱/۶۵	۲/۷۵	۹/۹۸	۱۳/۸	۰/۱	(hr) ساعات آفتابی	
۵۰/۸۳	-۰/۴۸	-۰/۰۲	۴/۱۲	۸/۱۱	۳۰	۰/۱	(mm) تبخیر	
۳۶/۳۳	-۰/۷۳	-۰/۴۸	۷/۵۰	۲۰/۷۸	۳۴/۸۰	-۳/۳۰	(Co) میانگین دما	متغیرهای خروجی
۳۶/۹۲	-۰/۸۹	-۰/۴۸	۹/۶۹	۲۶/۲۴	۴۵/۵۳	۰/۷۰	(Co) ۵ سانتی متر	
۳۵/۶۱	-۰/۷۹	-۰/۵۶	۹/۱۶	۲۵/۷۳	۳۹/۶۷	۰/۳۰	(Co) ۱۰ سانتی متر	
۳۲/۹۵	-۰/۷۹	-۰/۵۸	۸/۰۱	۲۴/۳۱	۳۶/۶۷	۲/۰۷	(Co) ۲۰ سانتی متر	
۳۱/۷۲	-۰/۸۵	-۰/۵۶	۷/۶۳	۲۴/۰۵	۳۷/۱۳	۳/۴۰	(Co) ۳۰ سانتی متر	
۲۷/۱۴	-۰/۹۲	-۰/۵۳	۶/۶۲	۲۴/۳۷	۳۵	۷/۳۳	(Co) ۵۰ سانتی متر	
۲۱/۵۲	-۰/۹۲	-۰/۵۰	۵/۰۸	۲۳/۵۹	۳۲/۹۳	۱۰/۶۰	(Co) ۱۰۰ سانتی متر	

جدول ۲. تعیین ساختار مدل شبکه عصبی مصنوعی برای اعماق ۱۰ و ۵۰ سانتی متر با استفاده از فرایند آزمون و خطا

عمق خاک	۱۰ سانتی متر		۵۰ سانتی متر	
	خطای آموزش	خطای صحت سنجی	خطای آموزش	خطای صحت سنجی
۱	۱/۵۸	۱/۷۵	۲/۳۸	۲/۴۲
۲	۱/۵۷	۱/۶۵	۲/۳۶	۲/۴۱
۳	۱/۶۵	۱/۷۱	۲/۱۶	۲/۲۵
۴	۱/۵۳	۱/۵۹	۲/۰۹	۲/۲۵
۵	۱/۵۵	۱/۶۵	۲/۱۲	۲/۲۲
۶	۱/۵۵	۱/۶۱	۲/۲۱	۲/۳۸
۷	۱/۵۵	۱/۶۰	۲/۱۲	۲/۲۲
۸	۱/۵۴	۱/۶۱	۲/۱۴	۲/۳۶
۹	۱/۵۲	۱/۶۴	۲/۱۷	۲/۳۵
۱۰	۱/۵۴	۱/۶۶	۲/۰۸	۲/۲۴
۱۱	۱/۵۱	۱/۴۲	۲/۰۳	۲/۲۲
۱۲	۱/۵۴	۱/۶۰	۱/۹۷	۲/۴۲
۱۳	۱/۵۴	۱/۶۰	۱/۹۹	۲/۲۸

جدول ۳. نتایج ارزیابی مدل های شبکه عصبی مصنوعی جهت شبیه سازی دمای اعماق مختلف خاک

عمق (سانتی متر)	ANFIS	
	R2	RMSE (Co)
۵	۰/۹۸	۱/۸۶
۱۰	۰/۹۸	۱/۵۸
۲۰	۰/۹۶	۱/۸۴
۳۰	۰/۹۵	۱/۸۹
۵۰	۰/۹۱	۲/۱۵
۱۰۰	۰/۸۰	۲/۳۹


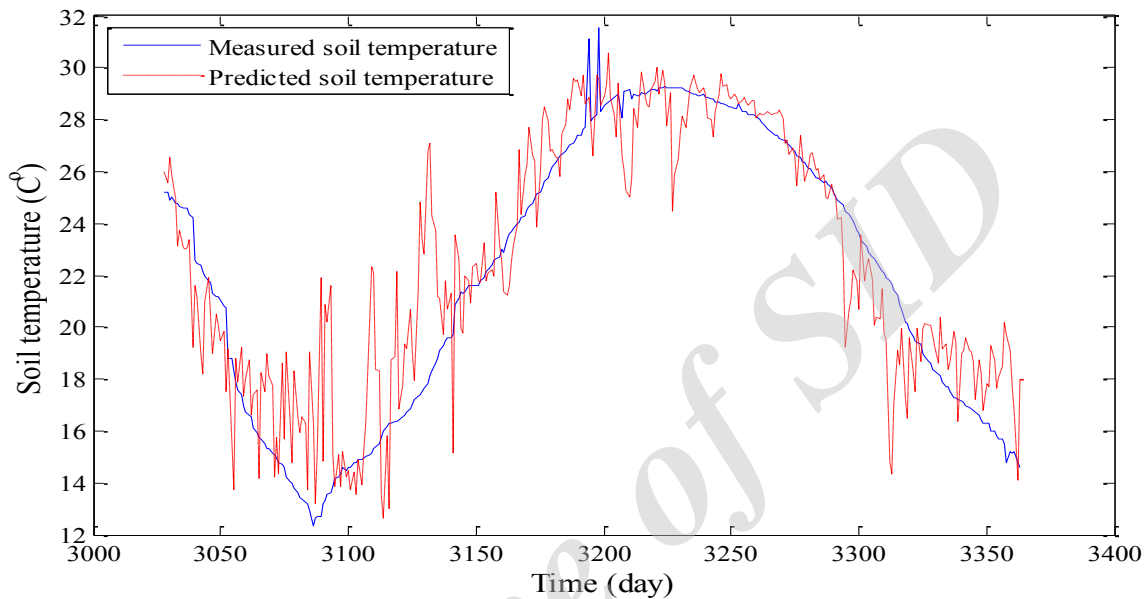
بیشتر مدل های به کار گرفته شده در لایه های سطحی نسبت به لایه های عمقی است.

نتایج ارزیابی مدل های شبکه عصبی مصنوعی در شبیه سازی دمای عمق های مختلف خاک در شکل ۵ نشان داده شده است. با توجه به شکل مشخص است که خطای مدل با افزایش عمق افزایش پیدا می کند به طوری که بیشترین خطای مدل در عمق ۱۰۰ سانتی متری و کمترین خطای مدل ها در عمق ۱۰ سانتی متر از سطح می باشد. نتایج جدول ۳ نیز نشان دهنده افزایش خطای مدل های شبکه عصبی مصنوعی در شبیه سازی تغییرات

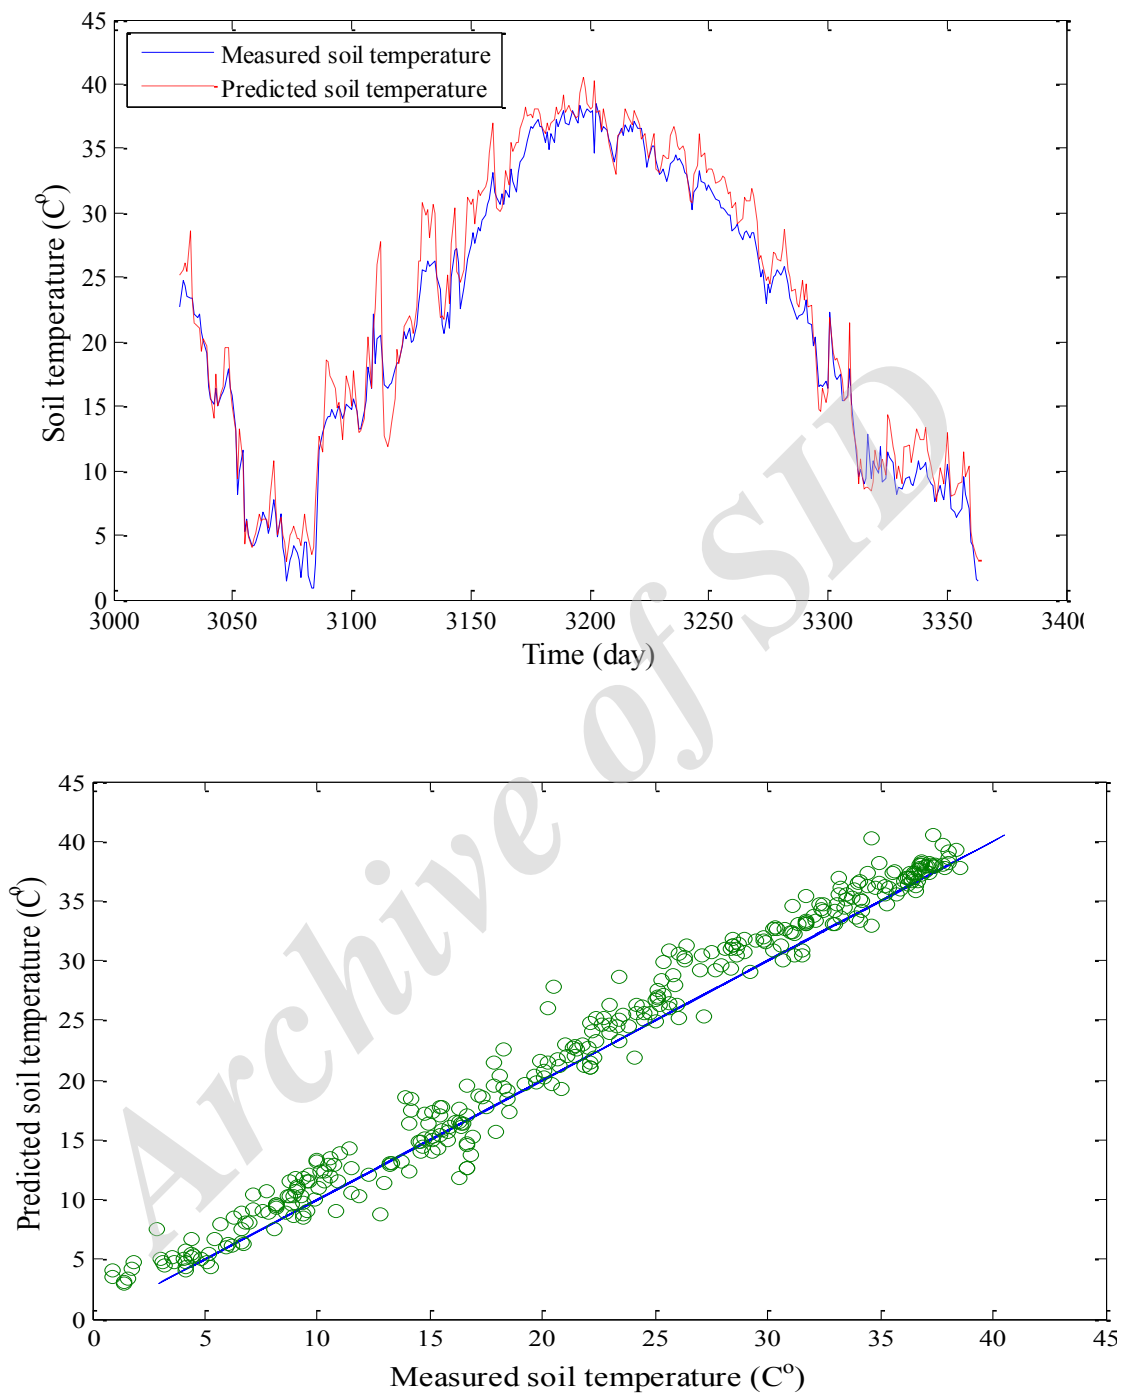
نمودار همبستگی داده های مشاهده ای و داده های شبیه سازی شده با استفاده از شبکه عصبی مصنوعی در شکل ۳ و ۴ نشان داده شده است. با توجه به نمودارها مشخص است که شبکه عصبی مصنوعی در شبیه سازی دمای خاک موفق است. در اینجا برای نمونه نتایج شبیه سازی مدل شبکه عصبی مصنوعی در عمق ۵ و ۱۰۰ سانتی متر آورده شده است. نکته قابل توجه در بررسی نمودارهای شکل ۵ این است که توافق بین داده های مشاهده ای و شبیه سازی شده در لایه های سطحی نسبت به لایه های عمقی بیشتر است که نشان دهنده کارایی

تحتانی نسبت به لایه‌های فوقانی است. به طوری که ضریب تغییرپذیری دمای خاک با افزایش عمق نسبت به لایه‌های سطحی کمتر است و کمتر تحت تأثیر متغیرهای اقلیمی از جمله دمای خاک قرار می‌گیرد.


دمای خاک در لایه‌های عمقی می‌باشد. علت اصلی افزایش کارایی مدل‌های هوش مصنوعی در شبیه‌سازی دمای خاک در لایه‌های سطحی نسبت به لایه‌های تحتانی عمدتاً مربوط به کاهش همبستگی بین پارامترهای اقلیمی و تغییرات دمای خاک در لایه‌های



شکل ۳. کارایی شبکه عصبی مصنوعی در شبیه‌سازی دمای خاک در عمق ۵ سانتی‌متر



شکل ۴. کارایی شبکه عصبی مصنوعی در شبیه‌سازی دمای خاک در عمق ۱۰۰ سانتی‌متر



شکل ۵- مقادیر خطای (RMSE) مدل‌های شبکه عصبی مصنوعی در شبیه‌سازی دمای اعماق مختلف خاک

دلیل این موضوع افزایش همبستگی بین متغیرهای ورودی و خروجی و نیز افزایش غیر خطی بودن روابط بین متغیرهای ورودی و خروجی در لایه‌های سطحی است. نتایج این مطالعه با نتایج پارسافر و معروفی [۱۹] مطابقت داشته و بیان می‌نماید که با افزایش عمق خطای مدل نیز افزایش پیدا می‌کند به عبارت دیگر، با توجه به ضرایب همبستگی و خطاهای به دست آمده می‌توان گفت برای عمق ۱۰۰ سانتیمتری خاک دارای دقت پایین، اما برای سایر عمق‌ها مطلوب و دارای دقت بالاتری می‌باشد. همچنین قائمی نیا و همکاران [۱۱] اظهار داشتند که با افزایش عمق صحت پیش‌بینی‌ها کاهش پیدا می‌کند به طوری که مقایسه مقادیر اندازه‌گیری و پیشگویی مدل روی دستگاه مختصات نشان داد که مدل سینوسی با افزایش عمق، مقادیر را کمتر از مقدار واقعی برآورد می‌نماید.

۴. بحث و نتیجه‌گیری

دمای خاک یکی از متغیرهای کلیدی در مطالعات منابع طبیعی و به‌خصوص مطالعات هیدرولوژی و برآورد مؤلفه‌های هیدرولوژیک از جمله جریان‌های سطحی و مقادیر تبخیر و تعرق دارد. در این مطالعه مدل شبکه عصبی مصنوعی جهت شبیه‌سازی دمای خاک در لایه‌های مختلف خاک مورد استفاده قرار گرفت. نتایج نشان‌دهنده افزایش ضریب تغییرات دمای خاک در لایه‌های سطحی نسبت به لایه‌های فوقانی است. نتایج همچنین نشان‌دهنده کارایی نسبتاً خوب مدل به کار گرفته شده جهت شبیه‌سازی و پیش‌بینی دمای خاک در اعماق مختلف خاک می‌باشد. تحلیل خطای مدل‌های هوش مصنوعی در شبیه‌سازی داده‌های دمای خاک در عمق‌های مختلف خاک نشان‌دهنده این است که مدل شبکه عصبی دقت بیشتری در شبیه‌سازی داده‌های دمای خاک در لایه‌های سطحی نسبت به لایه‌های عمقی دارد.

References

- [1] Amir Morady, K and Bahmani, O. 1393. Estimation of Daily Temperature of Soil Using Neural and Artificial Neural Networks, Soil Research Journal, Volume 28, Number 3, pp. 544-55

- [2] Bait varkeshi, M, Zare Abyaneh H, Maroufi S., SabZi Parvar and Soltani, F, 2009. Simulation of daily transpiration evapotranspiration of reference plant using artificial intelligence and empirical methods in comparison with lysimetric measurements in Hamadan semi-arid climate. *Journal of Water and Soil Conservation Studies*, Vol. 16, No. 4, pages 79-100
- [3] Béhaegel, M., SAILHAC, P., and MARQUIS G. 2007. On the use of surface and ground temperature data to recover soil water content information. *J. Appl. Geophys.*, 62: 234–243.
- [4] Bocock, K. L., Lindley, D. K., Gill, C. A., Adamson, J. K. and Webster, J. A. 1974. Harmonic analysis and synthesis: Basic principles of the technique and some applications to temperature data *Merewood Res. Dev.* No.54
- [5] Chio, J. S., Fermanian, T. W., Weh ner, D. J. and Spomer, L. A. 1988. Effect of temperature, moisture and soil texture on DCPA degradation. *Agron. J.* 80: 108-11.
- [6] Cigizoglu, H. K., Alp, M., (2008), “Generalized Regression Neural Network in Modeling River Sediment Yield”, *J. of Advances in Engineering Software*, 37, pp 63-68.
- [7] Coelho, L. D., Freire, R. Z., Santos, G. H. D., Mendes, N. 2009. Identification of temperature and moisture content fields using a combined neural network and clustering method approach, *International Communications in Heat and Mass Transfer*. doi: 10.1016/j.icheatmasstransfer.2009.01.012
- [8] Conard, V. and Pollock, L. W. 1950. *Methods in climatology*, Harvard Uni. Press, Cambridge Mass:119-133.
- [9] Elshorbagy, A. and Parasuraman, K., 2008. On the relevance of using artificial neural networks for estimating soil moisture content. *J Hydrol.* 362, 1– 18.
- [10] Gao, Z., Bian, L., Hu, Y., Wang, L. and Fan, J., 2007. Determination of soil temperature in an arid region. *J Arid Environ.* 71, 157-168.
- [11] Ghaemina A, Azimzadeh, H., Mobin, M., 2011, Simulation of temperature variations in different depths of soils and the study of some atmospheric factors of the effect of this problem (synoptic case study of Yazd). *Quarterly Journal of Iranian Pasture and Desert Research*, vol. 18 no. 1 pp. 42-57
- [12] Hann, C. E. 1977. *Statistical methods in hydrology*. Iowa State univ. Press.
- [13] Jang, J.S.R., 1993. ANFIS: Adaptive network based fuzzy inference system, *IEEE Trans. On System, Man, and Cybernetics*, 23(3): 665-685.
- [14] Jenkins, G. M. 1976. *Time series analysis, forecasting and control*, revised edn. Holden-Day, San Francisco.
- [15] Kemp, P. R., Cornelius, J. M., and Reynolds, J. F. 1992. A simple model for predicting soil temperatures in desert ecosystems. *Journal of Soil Science*, 153: 280–287.
- [16] Kuseokes, E., Liechty, H. O., Reed, D. D. and Dong, J. 1997. Relating site specific weather data to regional monitoring networks in the late states. *For. Sci.* 43: 447-452.
- [17] Mamdani, E.H. and Assilian, S., 1975. An experiment in linguistic synthesis with a fuzzy logic controller. *International Journal of Man-Machine Studies*, 7(1): 1-13.
- [18] Nayak, P.C., Sudheer, K.P., Rangan, D.M. and Ramasatri, K.S., 2004. A neuro-fuzzy computing technique for modeling hydrological time series. *Journal of Hydrology*, 291: 52-66.
- [19] Parsa Far, N, Maroufi, P., 2011, Estimation of Different Depth Temperatures from Air Temperature Using Frequency Relations, Neural Networks and Neural-Fuzzy Network (Case Study: Kermanshah Region), Vol. 3 No. 21, Page. 140-152
- [20] Sabziparvar, A., Zare Abyaneh, H., Biat varkeshi, M., 2010, Comparison of the findings of the comparative neuro-fuzzy inference network model with regression models for estimating soil temperature in three different climates. *Water and Soil Journal*. Volume 24, Number 2, June -, pp. 285-274
- [21] Yang, C. C., Parsher, S. O., Mehuys, G. R. and Panti, N. K. 1997. Application of artificial neural networks for simulation of soil temperature. *Agric. Eng* 40(3): 649-656.
- [22] Yin, X. and Arp, P.A. 1993. Predicting forest soil temperatures from monthly air temperature and precipitation records. *Can. J. For. Res.*, 23: 2521–2536.

Archive of SID